IN THE U.S. PATENT AND TRADEMARK OFFICE

In re application of: Samir NEFTI et al.

Conf.:

Appl. No.:

Group:

Filed:

August 12, 2003

Title:

Examiner:

METHOD OF AUTOMATIC PROCESSING OF A

SPEECH SIGNAL

CLAIM TO PRIORITY

Assistant Commissioner for Patents P.O. Box 1450 Alexandria, VA 22313-1450

August 12, 2003

Sir:

Applicant(s) herewith claim(s) the benefit of the priority filing date of the following application(s) for the above-entitled U.S. application under the provisions of 35 U.S.C. § 119 and 37 C.F.R. § 1.55:

Country

Application No.

Filed

FRANCE

02 13417

October 25, 2002

Certified copy(ies) of the above-noted application(s) is(are) attached hereto.

Respectfully submitted,

YOUNG & THOMPSON

Benoit Castel, Reg. No. 35,041

745 South 23rd Street
Arlington, VA 22202
Telephone (703) 521-2297

BC/ia

Telephone (703) 521-2297

Attachment(s): 1 Certified Copy(ies)

"• "		

REPUBLIQUE FRANÇAISE



BREVET D'INVENTION

CERTIFICAT D'UTILITÉ - CERTIFICAT D'ADDITION

COPIE OFFICIELLE

Le Directeur général de l'Institut national de la propriété industrielle certifie que le document ci-annexé est la copie certifiée conforme d'une demande de titre de propriété industrielle déposée à l'Institut.

Fait à Paris, le	1 1 JUIN 2003

Pour le Directeur général de l'Institut national de la propriété industrielle Le Chef du Département des brevets

Martine PLANCHE

INSTITUT
NATIONAL DE
LA PROPRIETE

SIEGE 26 bis, rue de Saint Petersbourg 75800 PARIS cedex 08 Téléphone : 33 (0)1 53 04 53 04 Téléphone : 33 (0)1 53 04 45 23

		<i>,</i>



1er dépôt BREVET D'INVENTION CERTIFICAT D'UTILITÉ

Code de la propriété intellectuelle - Livre VI



26 bis, rue de Saint Pétersbourg 75800 Paris Cedex 08 Téléphone : 33 (1) 53 04 53 04 Télécopie : 33 (1) 42 94 86 54

REQUÊTE EN DÉLIVRANCE page 1/2

	Cet imprimé est à remplir lisiblement à l'encre noire 39 540 W / 010801	
REMISE DES PIÈCES DATE LIEU 25 OCT 2002	NOM ET ADRESSE DU DEMANDEUR OU DU MANDATAIRE À QUI LA CORRESPONDANCE DOIT ÊTRE ADRESSÉE	
75 INPLPARIS N° D'ENREGISTREMENT NATIONAL ATTRIBUÉ PAR L'INPI DATE DE DÉPÔT ATTRIBUÉE	CABINET LAVOIX 2, Place d'Estienne d'Orves 75441 PARIS CEDEX 09	
DATE DE DÉPÔT ATTRIBUÉE PAR L'INPI 25 OCT. 20	002	
Vos références pour ce dossier BFF 02/0		
Confirmation d'un dépôt par télécopie	N° attribué par l'INPI à la télécople	
NATURE DE LA DEMANDE	Cochez l'une des 4 cases suivantes	
Demande de brevet Demande de certificat d'utilité	25	
Demande de certificat o utilité Demande divisionnaire		
	N° Date	
,,,,,,,,,,,,,,,,,,,,,,,,,,,,,,,,,,,,,,,	N° Date	
on demande de certificat d'utilité initiale Transformation d'une demande de	Date C	
brevet européen Démande de brevet initiale	N° Date	
TITRE DE L'INVENTION (200 caractères ou espaces maximum)		
DÉCLARATION DE PRIORITÉ	Pays ou organisation Date N°	
OU REQUÊTE DU BÉNÉFICE DE	Pays ou organisation	
LA DATE DE DÉPÔT D'UNE	Date N°	
DEMANDE ANTÉRIEURE FRANÇAISE	Pays ou organisation Date N°	
TOLK	S'il y a d'autres priorités, cochez la case et utilisez l'imprimé «Suite»	
DEMANDEUR (Cochez l'une des 2 casos)		
Nom	FRANCE TELECOM	
ou dénomination sociale		
Prénoms Forme juridique	Société Anonyme	
N° SIREN		
Code APE-NAF		
Domicile Rue	6, Place d'Alleray 75015 PARIS	
ou Code postal et ville		
Pays	FRANCE Française	
Nationalité N° de téléphone <i>(facultatif i</i>	N° de télécopie (facultatif)	
Adresse électronique (facultatif)		
	S'il y a plus d'un demandeur, c chez la cas et utilisez l'imprimé «Suite»	



Réservé à l'INPI

1er dépôt **BREVET D'INVENTION** CERTIFICAT D'UTILITÉ

REQUÊTE EN DÉLIVRANCE page 2/2





REMIS DATE	E DES PIÈCES	Heserve a l'INPI				
LIEU		OCT 2002				
η₀ υ.ε	75 IVI	PIPARIS				
	NAL ATTRIBUÉ PAR	6217 A . A . A . A	7		D8 540 W / 010801	
Vos	références p	our ce dossier :	BFF 02/0363	ACCIONATO DE MANTE CONTRACTO DE SECUENCIA DE COMPANSA DE LA COMPANSA DE LA COMPANSA DE LA COMPANSA DE LA COMPA		
1	eltatif)					
0	MANDATAIRI	(silyaliei)				
	Nom	the board of a day is a manage and the second of the secon	The state of the s		and the state of the state of the comment of the state of	
	Prénom		* *************************************			
	Cabinet ou So	ciété	CABINET LAVOIX			
		The contract and an incidence of the contract	and the second second		Company of the control of the contro	
R	N "de pouvoir de lien contrac	permanent et/ou				
	ue nen contrac	r transcription to the				
Name		Rue	2 Place d'E	2 Place d'Estienne d'Orves		
	Adresse	Code postal et ville	75441 PA	RIS CEDEX 09		
	Α	Pays	FRANCE			
	N° de téléphoi	ne (facultatif)	01 53 20 14 20			
	N° de télécopi	e (facultatif)	01 48 74 54 56			
	Adresse électr	onique (facultatif)	brevets@cab	inet-lavoix.com		
図	INVENTEUR	(s)	Les inventeurs so	nt nécessairement des	personnes physiques	
	Les demander	ırs et les inventeurs	□ Oui			
	sont les même	es personnes	🗷 Non: Dans	ce cas remplir le formu	laire de Désignation d'inventeur(s)	
0	RAPPORT DE	RECHERCHE	Uniquement pour	une demande de brevo	et (y compris division et transformation).	
		Établissement immédiat	[28]			
		ou établissement différé				
	Deference Adams	to the second	Uniquement pour	es personnes physiques	effectuant elles-mêmes leur propre dépôt	
		elonné de la redevance In deux versements)	☐ Oui			
	,,	,	Non			
O	RÉDUCTION	DU TAUX	Uniquement now	· les personnes physiqu	e AC	
-	DES REDEVA				invention (joindre un avis de non-imposition)	
			Obtenue antérieurement à ce dépôt pour cette invention (joindre une copie de la			
			indiquer sa référence): AG			
				8		
		utilisé l'imprimé «Suite»,				
CONT. BANCON.	THE RESERVE AND THE PERSON NAMED IN	ombre de pages Jointes	C. JACOBSON			
	SIGNATURE I OU DU MAND	DU DEMANDEUR	n° 92.1119	TT	VISA DE LA PRÉFECTURE OU DE L'INPI	
6		ité du signataire)		7()	OO DE E IIII I	
					M. ROUHET	
					9 र र ∵	
America areas				CONTRACTOR OF THE PROPERTY OF THE PARTY OF T		

10

15

20

25

30

La présente invention concerne un procédé de traitement automatique d'un signal de parole comportant une étape d'alignement entre une modélisation d'un texte et un signal de parole correspondant à l'élocution de ce texte.

De tels procédés sont utilisés, par exemple, dans le cadre de la synthèse de parole ou encore de la détermination de bases de données d'apprentissage pour des systèmes de reconnaissance vocale.

En référence à la figure 1, on va décrire un procédé de traitement automatique de l'état de l'art dans le cadre de la synthèse vocale.

Ce procédé comporte une étape 2 automatique de détermination d'une séquence de modèles probabilistes représentative d'un texte donné.

De manière classique, les modèles probabilistes utilisés sont un nombre fini de modèles dits « modèles de Markov cachés» ou HMM (Hidden Markov Model) qui décrivent la probabilité de réalisation acoustique d'unités symboliques de nature phonologique.

Parallèlement à l'étape 2, le procédé comporte une étape 4 de détermination d'une séquence de trames de données numériques correspondant à l'élocution du même texte donné, ou trames acoustiques.

Le procédé comporte ensuite une étape 6 d'alignement entre la séquence de trames acoustiques et la séquence de modèles.

Ainsi, à chaque unité symbolique d'ordre phonolgique représentée par un ou plusieurs modèles, est associée une sous-séquence de trames acoustiques dite « segment acoustique ».

...

Par exemple, ces associations entre une unité symbolique et un segment acoustique sont mémorisées individuellement afin de permettre ultérieurement la synthèse de parole en générant une séquence de trames acoustiques correspondant à un autre texte que le texte donné précité.

Cependant, des variations peuvent apparaître lors de l'étape 6 d'alignement résultant notamment de différences entre le signal de parole réellement prononcé et la séquence de modèles correspondant à une prononciation théorique.

En effet, l'étape 2, de détermination d'une séquence de modèles, associe à un texte donné une unique séquence de modèle.

Cependant, l'élocution de ce texte peut donner lieu à différents signaux de parole du fait de l'influence du locuteur. Notamment, des unités phoné-

10

15

20

25

30

tiques, ou phonèmes peuvent être associés entre eux comme dans le cas de liaisons, ou encore d'autres phonèmes peuvent être supprimés ou rallongés.

De telles variations peuvent entraîner l'association d'un modèle avec un segment acoustique erroné et/ou décalé, introduisant ainsi une erreur d'alignement dans les segments acoustiques suivants.

Il résulte de ces variations, la nécessité d'introduire pour chaque association entre un segment acoustique et un ou plusieurs modèles, un indice de confiance, lors d'une étape 8, qui permet d'attribuer un score probabiliste à chaque association.

Cependant, dans les procédés de l'état de l'art, ces indices de confiance calculés pour chaque modèle ne sont pas d'une grande précision.

Notamment, ces indices de confiance sont calculés essentiellement à partir des probabilités de transition d'un modèle à l'autre. Ainsi, ces indices de confiance sont directement calculés pour un segment de trames acoustiques entraînant un niveau de précision peu élevé.

De manière classique, ces indices de confiance permettent uniquement de rejeter certaines associations qui sont corrigées manuellement par des spécialistes lors d'une étape 10 de correction longue et coûteuse.

Il apparaît donc que dans les procédés de l'état de l'art, la précision des indices de confiance est insuffisante rendant ainsi les procédés de traitement longs et coûteux de par la nécessité d'interventions humaines de correction.

Le but de la présente invention est de remédier à ce problème, en définissant un procédé automatique de traitement comportant un indice de confiance de précision accrue.

L'invention a pour objet un procédé de traitement automatique d'un signal de parole comportant :

- une étape automatique de détermination d'au moins une séquence de modèles probabilistes issus d'un répertoire fini de modèles, chaque séquence décrivant la probabilité de réalisation acoustique d'une séquence d'unités symboliques de nature phonologique issues d'un alphabet fini, ladite séquence d'unités symboliques correspondant à au moins un texte donné et lesdits modèles probabilistes comportant chacun un processus aléatoire observable correspondant à la réalisation acoustique d'unités symboliques et un processus

10

15

20

25

30

aléatoire non observable possédant des propriétés probabilistes connues dites propriétés de Markov ;

- une étape de détermination d'une séquence de trames de données numériques, dites trames acoustiques, représentatives de propriétés acoustiques d'un signal de parole ;
- une étape d'alignement entre ladite séquence de trames acoustiques et ladite séquence de modèles, chaque modèle étant associé à une sous-séquence de trames acoustiques, formant un segment acoustique, et chaque valeur du processus non observable de chaque modèle étant associée à une sous-séquence de trames acoustiques formant un sous-segment acoustique pour délivrer une séquence de valeurs de processus non observables associant une valeur à chaque trame acoustique, dite séquence alignée; et
- une étape de détermination d'un indice de confiance d'alignement acoustique pour chaque association entre un modèle et un segment acoustique, dit indice de confiance d'alignement de modèle et correspondant à une estimation de la probabilité a posteriori du modèle étant donné l'observation du segment acoustique correspondant, dite probabilité de modèle a posteriori.

Chaque étape de détermination d'un indice de confiance d'alignement pour un modèle comprend le calcul de la valeur dudit indice au moins à partir d'une combinaison :

- de la probabilité d'observation de chaque trame acoustique étant donnée la valeur du processus non observable, dite probabilité de modèle et déterminée à partir de propriétés mathématiques connues du modèle et de ladite séquence de trames acoustiques ;
- de probabilités de réalisation a priori de tous les modèles dudit répertoire, indépendamment les uns des autres, dites probabilités de modèles a priori ; et
- de l'estimation analytique de la durée moyenne d'occupation des valeurs du processus non observable du modèle.

Suivant d'autres caractéristiques :

- chaque étape de détermination d'un indice de confiance acoustique pour un modèle comporte une sous-étape de détermination de l'estimation de la probabilité a priori de chaque valeur du processus non observable du modèle, dite probabilité de valeur a priori, réalisée à partir de ladite estimation analytique

20

30

de la durée moyenne d'occupation des valeurs du processus non observable du modèle ;

- chaque étape de détermination d'un indice de confiance d'alignement pour un modèle comporte une sous-étape de détermination d'un indice de confiance pour chaque trame acoustique formant le segment acoustique associé audit modèle et une sous-étape de combinaison des indices de confiance de chaque trame dudit segment afin de délivrer ledit indice de confiance dudit modèle ;
- chaque sous-étape de détermination d'un indice de confiance pour 10 une trame donnée comporte :
 - une sous-étape de calcul initial combinant la probabilité de modèle, la probabilité de modèle a priori du modèle en cours et la durée moyenne d'occupation des valeurs non observables pour toutes les valeurs du processus non observable de ladite séquence alignée et du modèle en cours ;
- une sous-étape de calcul du produit de la probabilité de modèle, de la probabilité de modèle a priori et de la probabilité de valeur a priori, réalisée pour chaque valeur du processus non observable de tous les modèles possibles dudit répertoire fini de modèles ; et
 - une sous-étape de sommation de tous lesdits produits pour tous les modèles possibles dudit répertoire fini de modèles, afin de délivrer ledit indice de confiance de ladite trame acoustique donnée à partir des résultats desdites sous-étapes ;
 - ladite étape automatique de détermination d'une séquence de modèles probabilistes correspondant à un texte donné comporte :
- une sous-étape d'acquisition d'une représentation graphémique dudit texte donné ;
 - une sous-étape de détermination d'une séquence d'unités symboliques issues d'un alphabet symbolique fini à partir de ladite représentation graphémique; et
 - une sous-étape automatique de modélisation de ladite séquence d'unités par sa décomposition sur une base desdits modèles probabilistes afin de délivrer ladite séquence de modèles probabilistes ;
 - ladite sous-étape de modélisation associe un unique modèle probabiliste à chaque unité symbolique de ladite séquence d'unités symboliques ;

15

20

25

- ladite étape de détermination d'une séquence de trames numériques comporte :
- une sous-étape d'acquisition d'un signal de parole correspondant à l'élocution dudit texte donné, adaptée pour délivrer une séquence d'échantillons numériques dudit signal de parole ; et
- une sous-étape d'analyse spectrale desdits échantillons pour délivrer une décomposition du spectre fréquentiel dudit signal de parole sur une échelle non linéaire, ladite décomposition formant ladite séquence de trames acoustiques ;
- ladite sous-étape d'analyse spectrale correspond à une sous-étape de transformation de Fourier dudit signal de parole, de détermination de la distribution de son énergie sur une échelle non linéaire par filtrage, et de transformation en cosinus ;
 - ladite étape d'alignement entre ladite séquence de trames acoustiques et ladite séquence de modèles comporte :
 - une sous-étape de calcul d'une pluralité d'alignements possibles chacun associé à un indice de pertinence ; et
 - une sous-étape de sélection d'un unique alignement parmi ladite pluralité d'alignements possibles ;
 - ladite sous-étape de détermination d'une pluralité d'alignements possibles comprend le calcul d'au moins un alignement optimal, tel que déterminé par un algorithme dit de Viterbi ;
 - il comporte en outre une étape de modification locale de ladite séquence de modèles, en fonction desdits indices de confiance d'alignement déterminés pour chaque modèle de ladite séquence de modèles ;
 - ladite étape de modification locale comprend une sous-étape de suppression d'un modèle de ladite séquence de modèles;
 - ladite étape de modification locale comporte une sous-étape de substitution d'un modèle de ladite séquence de modèles par un autre modèle ;
 - ladite étape de modification locale comporte une sous-étape d'insertion d'un modèle entre deux modèles de ladite séquence de modèles ;
 - les dites étapes d'alignement et de calcul d'un indice de confiance sont répétées après chaque étape de modification locale de ladite séquence de modèles ;

10

15

20

25

30

- ladite étape de détermination d'au moins une séquence de modèles est adaptée pour la détermination d'une séquence de modèles correspondant à un texte donné et en ce que ladite séquence de trames acoustiques est représentative de propriétés d'un signal de parole correspondant à la locution dudit même texte donné.

- ladite étape de détermination de séquences de modèles est adaptée pour la détermination d'une pluralité de séquences de modèles correspondant chacun à un texte donné et en ce que ladite séquence de trames acoustiques est représentative de propriétés d'un signal de parole correspondant à la locution d'un texte quelconque, ledit procédé comportant une étape de sélection d'une ou plusieurs séquences de modèles parmi ladite pluralité, pour la réalisation de ladite étape de détermination d'indices de confiance.

- lesdits modèles sont des modèles dont les processus observables sont à valeurs discrètes, les valeurs des processus non observables étant les · états de ces processus ;
- lesdits modèles sont des modèles dont les processus non observables sont à valeurs continues.

L'invention sera mieux comprise à la lecture de la description qui va suivre, donnée uniquement à titre d'exemple et faite en se référant aux dessins annexés, sur lesquels, outre la Fig.1 déjà citée représentant un organigramme d'un procédé de traitement automatique de l'état de l'art dans le cadre de la synthèse vocale :

- la Fig.2 représente un organigramme d'un procédé de traitement selon l'invention dans le cadre de la synthèse vocale ; et
- la Fig.3 représente le détail de signaux spécifiques au cours du procédé décrit en référence à la figure 2.

Le procédé de l'invention décrit sur la figure 2, comporte une étape 20 de détermination automatique d'une séquence de modèles probabilistes représentative d'un texte donné.

Dans le mode de réalisation décrit, cette étape 20 comporte une sousétape 22 d'acquisition d'une représentation symbolique d'un texte donné, telle qu'une représentation graphémique ou orthographique.

Par exemple, cette représentation graphémique est un texte rédigé à l'aide de l'alphabet latin, désigné par la référence TXT sur la figure 3.

10

15

20

25

30

Le procédé comporte ensuite une sous-étape 24 de détermination d'une séquence d'unités symboliques de nature phonologique d'un alphabet fini, à partir de ladite représentation graphémique.

Une telle séquence d'unités symboliques, repérée par la référence U sur la figure 3, est par exemple composée de phonèmes extraits d'un alphabet phonétique.

Cette sous-étape 24 est réalisée automatiquement aux moyens de techniques classiques de l'état de l'art, telles que phonétisation ou autres.

Ainsi, par exemple, le texte « monsieur » en langue française est représenté à l'issue de la sous-étape 24, par la séquence d'unités phonétiques : $[m]-[\partial]-[s]-[j]-[\emptyset]$.

Notamment, cette sous-étape 24 met en œuvre un système de phonétisation automatique utilisant des bases de données et permettant de décomposer n'importe quel texte sur un alphabet symbolique fini.

L'étape 20 comporte ensuite une sous-étape 26 automatique de modélisation de la séquence U d'unités phonétiques par sa décomposition sur une base de modèles probabilistes de modèles de Markov cachés, couramment désignés HMM.

Dans le mode de réalisation décrit, les modèles de la séquence sont référencés H₁ à H_N sur la figure 3 et sont des modèles discrets comportant chacun un processus aléatoire observable correspondant à une réalisation acoustique et un processus aléatoire non observable désigné Q et possédant des propriétés probabilistes connues dites propriétés de Markov, selon lesquelles la réalisation de l'état futur d'un processus aléatoire ne dépend que de l'état présent de ce processus.

Ces modèles sont définis préalablement, par exemple à l'aide de réseaux neuronaux permettant de déterminer l'ensemble de leurs paramètres et notamment, des probabilités de maintien dans un état caché donné ainsi que des probabilités de transition entre l'état caché final d'un modèle et l'état caché initial d'un autre modèle.

Les propriétés mathématiques connues des modèles de Markov permettent de déterminer la probabilité d'observation d'une réalisation acoustique désignée O_t , étant donné l'état du processus non observable Q, dite probabilité de modèle, notée P_m , et correspondant à :

$$P_m = P\left(O_t | Q_t\right)$$

10

15

20

25

30

On rappelle qu'une telle expression est une probabilité conditionnelle et correspond à la probabilité d'observation de la variable aléatoire O_t étant supposé réalisé un état donné Q_t du processus aléatoire Q.

Ces modèles de Markov sont issus d'un répertoire fini comportant par exemple 36 modèles différents référencés λ_1 à λ_I et sont associés aux unités symboliques de l'alphabet symbolique cité précédemment.

Dans le mode de réalisation décrit, chaque unité symbolique est associée à un unique modèle de Markov caché, de sorte que la séquence U d'unités phonétiques permet de déterminer directement une séquence H_1 à H_N , notée H_1^N , de modèles de Markov cachés décrivant la probabilité de réalisation acoustique de la séquence U d'unités symboliques.

Ainsi, l'étape 20 permet la détermination automatique d'une séquence H_1^N de modèles correspondant à la phonétisation automatique d'un texte donné.

Parallèlement à l'étape 20 de détermination de la séquence H_1^N de modèles, le procédé comporte de manière classique, une étape 40 de détermination d'une séquence de trames numériques, dites trames acoustiques, représentative de propriétés acoustiques d'un signal de parole correspondant à l'élocution du texte donné TXT.

Dans le mode de réalisation décrit, cette étape 40 comporte une sousétape 42 d'acquisition d'un signal de parole, identifié par la référence s(t) sur la figure 3, et correspondant à l'élocution du texte donné TXT.

Cette sous-étape 42 permet l'acquisition de la forme temporelle du signal de parole s(t) lequel est numérisé et échantillonné de sorte que la sous-étape 42 délivre une séquence d'échantillons numériques du signal de parole s(t).

Ainsi que cela a été dit précédemment, le signal de parole s(t) est directement lié aux caractéristiques d'élocution du locuteur de sorte que des variations significatives peuvent apparaître entre différentes locutions et qu'une pluralité de signaux acoustiques peuvent être considérés comme représentatifs du même texte TXT.

10

15

20

25

30

L'étape 40 comporte ensuite une sous-étape 44 d'analyse spectrale des échantillons numériques du signal de parole s(t) pour en délivrer une décomposition du spectre fréquentiel.

De manière classique, cette analyse spectrale est une analyse dite «MFCC» (Mel Frequency Cepstrum Coefficient) qui tient compte des propriétés non linéaires de la perception auditive et d'une déconvolution entre l'onde acoustique et les caractéristiques de timbre.

Dans le mode de réalisation décrit, cette analyse est réalisée sur une fenêtre glissante de type Hamming dont le résultat forme une séquence, référencée O_1^T sur la figure 3, de trames acoustiques ou vecteurs acoustiques référencés O_1 à O_T .

La sous-étape 44 d'analyse spectrale correspond par exemple à une transformation de Fourier du signal de parole s(t), à une détermination de la distribution de son énergie sur une échelle non linéaire par filtrage puis à une transformation en cosinus.

Le procédé comporte ensuite une étape 60 d'alignement entre la séquence O_1^T de trames acoustiques et la séquence H_1^N de modèles probabilistes.

Notamment, cette étape 60 d'alignement permet la sélection d'un alignement optimal au sens de l'algorithme dit de Viterbi.

Ainsi, cette étape 60 d'alignement comporte une sous-étape 62 de calcul d'une pluralité d'alignements possibles, chacun associé à un indice de vraisemblance et une sous-étape 64 de sélection d'un unique alignement parmi ladite pluralité d'alignements possibles.

De telles techniques d'alignements sont connues de l'état de l'art et permettent de délivrer une séquence de trames acoustiques étiquetées de sorte que chaque modèle H_n de la séquence de modèles H_1^N est associé à une sous-séquence $O(H_n)$ de trames acoustiques formant un segment acoustique.

De même, chaque état du processus non observable Q de chaque modèle H_n est associé à une sous-séquence de trames acoustiques formant un sous-segment acoustique ainsi que cela est représenté en référence à la figure 3.

Ainsi, une étiquette de début et une étiquette de fin sont déterminées pour chaque segment acoustique $O(H_n)$ de la séquence \mathcal{O}_1^T , associé à un modèle H_n donné de la séquence H_1^N .

Cette étape 60 permet également de délivrer une séquence $\widetilde{\mathcal{Q}}_t$ d'états non observable, dite séquence alignée, associant à chaque trame acoustique O_t un état non observable donné d'un modèle donné, noté q^i_j et correspondant au jème état de ième modèle de la séquence ainsi que cela est représenté sur la figure 3.

Le procédé comporte ensuite une étape 80 de détermination d'un in-10 dice de confiance d'alignement acoustique pour chaque association entre un modèle H_n et un segment acoustique O(H_n).

Cet indice de confiance est appelé indice de confiance d'alignement de modèle, noté l_n , et correspond à une estimation de la probabilité a posteriori du modèle étant donné l'observation du segment acoustique correspondant noté P_{mp} et correspondant à :

$$P_{mp} = P(H_n | O(H_n))$$

5

15

20

25

Dans le cadre de l'invention, chaque étape 80 de détermination d'un indice de confiance d'alignement I_n pour un modèle H_n est réalisé à partir d'une combinaison :

- de la probabilité d'observation de chaque trame acoustique étant donné la valeur du processus non observable du modèle correspondant, soit encore la probabilité de modèle P_m définie précédemment ;
- de probabilités de réalisation a priori de tous les modèles λ_1 à λ_I du répertoire, indépendamment les uns des autres, dites probabilités de modèle a priori et notées $P(\lambda_i)$; et
- du temps moyen de séjour sur chacun des états q^i_j du modèle H_n , noté $\overline{d}(q^i_j)$, calculé à partir de paramètres caractéristiques du modèle H_n et en particulier des paramètres de transition entre les états non observables.

La probabilité de modèles P_m est déterminée à partir des propriétés probabilistes connues du modèle H_n et de la séquence de trames acoustiques observée \mathcal{O}_1^T .

Les probabilités de modèle a priori $P(x_i)$ sont, par exemple, estimées préalablement par comptage des occurrences de phonèmes à partir de transcriptions graphémiques et/ou phonétiques.

Le temps moyen de séjour permet notamment l'estimation de la probabilité a priori de chaque valeur ou état du processus non observable Q d'un modèle H_n , dite probabilité de valeur a priori notée P_{vp} qui s'exprime sous la forme de probabilités conditionnelles par :

$$P_{vp} = P(q^i_j | \lambda_i)$$

et qui correspond à la probabilité a priori d'être dans un état non observable donné référencé q_j d'un modèle χ_i donné, noté q_j^i ainsi que cela a été décrit précédemment.

Les séquences étant dans des relations d'ordre temporel, les probabilités P_{vp} peuvent être exprimées de manière analytique par le ratio entre le temps moyen passé sur un état q^i_j , noté \overline{d} $\left(q^i_j\right)$, et le temps moyen d'occupation du modèle λ_i noté \overline{d} $\left(\lambda_i\right)$ et correspondant à la sommes des temps moyens de séjour sur chacun des états le constituant.

On peut alors écrire la relation analytique générale suivante :

$$\mathsf{P}_{\mathsf{vp}} \# \frac{\overline{d} \left(q_{j}^{i} \right)}{\overline{d} \left(\lambda_{i} \right)}$$

En fonction des modes de réalisation, le procédé de l'invention peut recevoir directement les P_{vp} , par exemple calculés préalablement et stockés dans une mémoire, ou encore recevoir les estimations $\overline{d}\left(q^i_j\right)$ de la durée moyenne d'occupation des états des processus non observables du modèle et effectuer le calcul lors d'une sous-étape de détermination de la probabilité de valeur a priori P_{vp} .

Il apparaı̂t alors que l'indice de confiance I_n peut s'exprimer selon la relation suivante :

25

5

10

15

$$I_{n} = \log \left[\frac{P(O_{t}|\widetilde{Q}_{t}) \frac{\overline{d}(\widetilde{Q}_{t})}{\overline{d}(H_{n})} P(H_{n})}{\sum_{i=1}^{l} \sum_{j=1}^{J(i)} P(O_{t}|Q_{t} = q_{j}^{i}) \frac{\overline{d}(q_{j}^{i})}{\overline{d}(\lambda_{i})} P(\lambda_{i})} \right]$$

10

15

20

25

Dans cette relation, \widetilde{Q}_t correspond à l'instant de la séquence alignée délivrée à l'issue de la sous-étape 64 et donc dans le mode de réalisation décrit, à une séquence d'états optimale au sens de l'algorithme de Viterbi s'étendant entre les instants t=b(n) et t=e(n) correspondant respectivement au début et à la fin de la séquence d'observation $O(H_n)$.

Le terme \overline{d} $\left(\widetilde{\mathcal{Q}}_{l}\right)$ correspondant à la durée moyenne de l'état à l'instant t de la séquence alignée et le terme \overline{d} (H_{n}) correspondant à la durée moyenne du nème modèle de la séquence H_{1}^{N} , ils sont tous deux obtenus à partir de la durée moyenne d'occupation des états non observables notée \overline{d} $\left(q_{j}^{i}\right)$ de manière générale.

Enfin, l'indice i permet de parcourir les modèles λ_1 à λ_I du répertoire de modèles et l'indice j permet de parcourir les états non observables 1 à J(i) de chaque modèle.

Afin de mettre en oeuvre cette relation, l'étape 80 comporte une sousétape 82 de calcul initial au cours de laquelle le numérateur de la relation est calculé pour une trame donnée.

Au cours de cette sous-étape 82 la probabilité de modèle $P_m = P(O_t | \widetilde{Q}_t)$ est combinée avec la probabilité de modèle a priori du modèle en cours $P(H_n)$, la durée moyenne d'occupation de la séquence alignée $\overline{d}(\widetilde{Q}_t)$ et la durée moyenne du modèle en cours $\overline{d}(H_n)$.

L'étape 80 comporte ensuite une sous-étape 84 de calcul du produit de la probabilité de modèles P_m avec la probabilité de modèle a priori $P(\chi_i)$ et la probabilité de valeurs a priori P_{vp} . Cette sous-étape 84 est réalisée pour tous les états non observables de tous les modèles possibles du répertoire fini de modèles.

Par la suite, le procédé comporte une étape 86 de sommation de tous les produits déterminés précédemment pour tous les modèles possibles λ_1 à λ_I du répertoire fini de modèles.

On détermine ainsi un indice de confiance pour une trame acoustique 5 donnée.

Le procédé comporte ensuite une étape 88 de combinaison des indices de confiance de chaque trame du segment acoustique donné afin de délivrer l'indice de confiance I_n du modèle H_n considéré.

La relation définissant l_n peut se ramener à l'équation algorithmique 10 suivante :

$$I_{n} = \sum_{t=b(n)}^{e(n)} \left[\log P(O_{t} | \widetilde{Q}_{t}) + \log \overline{d} \left(\widetilde{Q}_{t} \right) - \log \overline{d} \left(H_{n} \right) \right]$$

$$+ \log P(H_{n})$$

$$- \log \left[\sum_{i=1}^{I} \sum_{j=1}^{J(i)} P(O_{t} | Q_{t} = q_{j}^{i}) \frac{\overline{d} \left(q_{j}^{i} \right)}{\overline{d} \left(\lambda_{i} \right)} P\left(\lambda_{i} \right) \right]$$

De ce fait, les sous-étapes 82, 84 et 86 de l'étape 80 peuvent être décrites de manière algorithmique sous la forme suivante :

On définit un accumulateur PO puis on effectue les calculs suivants :

PO = 0;

Pour chaque modèle λ_i du répertoire, avec i compris entre 1 et l et 20 pour chaque état j du modèle λ_i , avec j compris entre 1 et J(i), on calcule :

$$PO = PO + P(|Q_t||q_j^i) \frac{\overline{d}(q_j^i)}{\overline{d}(\lambda_i)} P(\lambda_i) ;$$

$$I_n = I_n + \log P(O_t|\widetilde{Q}_t) ;$$

$$I_n = I_n + \log \overline{d}(q_t^n) ;$$

$$I_n = I_n - \log \overline{d}(H_n) ;$$

$$I_n = I_n + \log P(H_n) ;$$

$$I_n = I_n - PO.$$

Dans les relations précédentes, la valeur de l'indice précédente l_n est successivement instanciée à la valeur courante.

10

15

20

25

30

Avantageusement, le procédé comporte ensuite une sous-étape 90 de normalisation de l'indice de confiance d'alignement afin de délivrer un indice de confiance normalisé par rapport à la durée totale du modèle.

Ainsi, l'étape 80 délivre à partir de la probabilité de modèles P_m de la probabilité de modèle a priori $P(\chi_i)$ et de la durée moyenne d'occupation des états non observables $\overline{d}\left(q_i^i\right)$ l'indice de confiance d'alignement I_n .

Cet indice de confiance est d'une très grande fiabilité du fait notamment qu'il est calculé à partir de probabilités de valeur a priori P_{vp} estimée de manière analytique à partir de la durée moyenne d'occupation des états du processus non observable permettant ainsi de prendre en compte le temps passé dans chacun des états cachés et donc de prendre en compte les caractéristiques temporelles de la séquence de modèles H_1^N .

Par la suite, le procédé comporte une étape 100 de modification locale de la séquence H_1^N en fonction des indices de confiance d'alignement I_n déterminés pour chaque modèle de la séquence.

Ainsi, lors de l'étape 100, une décision permettant soit d'accepter soit de rejeter un modèle est prise pour chaque modèle de la séquence H_1^N .

Dans le mode de réalisation décrit, cette décision est prise automatiquement en fonction de la mesure de confiance I_n déterminée lors de l'étape 80 et d'un point de fonctionnement considéré comme un seuil d'acceptation ou de rejet du modèle.

Lorsque un modèle est rejeté, l'étape 100 de modification locale comporte alors alternativement une sous-étape de suppression, de substitution ou d'insertion d'un modèle.

Ainsi, un ou plusieurs modèles de la séquence de modèles H_1^N peuvent, manuellement ou automatiquement, être supprimés, remplacés ou encore un ou plusieurs nouveaux modèles peuvent être intercalés entre deux modèles de la séquence.

Avantageusement, la séquence ainsi modifiée est alors utilisée à nouveau dans le procédé pour être à nouveau alignée avec la séquence de trames acoustiques O_1^T lors de l'étape 60 et donner lieu à un nouveau calcul d'un indice

10

15

20

25

30

de confiance pour chaque association entre un modèle et un segment acoustique lors de l'étape 80.

Les étapes 60, 80 et 100 sont réitérées jusqu'à ce qu'il n'y ait plus de modèle rejeté ou encore qu'il n'y ait plus de modifications possibles de sorte que la séquence de trames étiquetées délivrée correspond à la meilleure hypothèse de décodage possibles.

Il apparaît donc que le procédé de l'invention permet la définition d'un indice de confiance d'une précision accrue. L'utilisation de cet indice permet notamment d'automatiser l'ensemble du procédé de traitement d'un signal de parole, de définir des modifications automatiques et d'obtenir un résultat optimisé.

Le procédé décrit peut être mis en oeuvre par des moyens logiciels et/ou matériels tels que des ordinateurs, des micro-processeurs, ou tout autre équipement adapté.

Le procédé décrit peut par exemple être utilisé dans des systèmes de synthèse vocale ou de constitution de bases de données d'apprentissage pour des systèmes de reconnaissance vocale et permet, du fait de l'utilisation d'un indice de confiance de grande précision et du rebouclage après une modification automatique, d'obtenir des séquences de trames étiquetées fiables et exploitables directement sans requérir d'intervention humaine.

Dans le cadre de la synthèse vocale, ainsi que cela a été décrit, la séquence de modèles et la séquence de trames acoustiques correspondent au même texte.

En variante, le procédé de l'invention peut être utilisé dans des systèmes de reconnaissance vocale par exemple pour former des bases de données d'échantillons de reconnaissance ou encore pour permettre de reconnaître un énoncé dans un répertoire de séquences de modèles.

Par exemple, les séquences candidates de modèle prédéterminées sont alignées successivement avec la séquence de trames acoustiques dite séquence cible et les indices de confiance de chaque modèle sont combinés sur l'ensemble de la séquence afin de délivrer une mesure de similitude entre la séquence de modèles et la séquence de trames acoustiques. L'association ayant la mesure de similitude la plus élevée est retenue.

Alternativement, la séquence sélectionnée est obtenue par modification à chaque rebouclage de manière similaire au mode de réalisation décrit précédemment.

Enfin, dans l'exemple décrit, les modèles de Markov cachés sont des modèles dont les processus non observables sont à états discrets. Cependant, le procédé peut également être réalisé avec des modèles dont les processus non observables sont à valeurs continues.

REVENDICATIONS

- 1. Procédé de traitement automatique d'un signal de parole comportant :
- une étape (20) automatique de détermination d'au moins une séquence (H_1^N) de modèles probabilistes (H_n) issus d'un répertoire fini de modèles $(\lambda_1 \ \ \dot{a} \ \ \lambda_I)$, chaque séquence (H_1^N) décrivant la probabilité de réalisation acoustique d'une séquence (U) d'unités symboliques de nature phonologique issues d'un alphabet fini, ladite séquence (U) d'unités symboliques correspondant à au moins un texte donné (TXT) et les dits modèles probabilistes (λ_i) comportant chacun un processus aléatoire observable correspondant à la réalisation acoustique d'unités symboliques et un processus aléatoire non observable (Q) possédant des propriétés probabilistes connues dites propriétés de Markov;
 - une étape (40) de détermination d'une séquence (\mathcal{O}_{1}^{T}) de trames de données numériques, dites trames acoustiques, représentatives de propriétés acoustiques d'un signal de parole (s(t));

15

- une étape (60) d'alignement entre ladite séquence (O_1^T) de trames acoustiques et ladite au moins une séquence (H_1^N) de modèles, chaque modèle (H_n) étant associé à une sous-séquence ($O(H_n)$) de trames acoustiques, formant un segment acoustique, et chaque valeur du processus non observable (Q) de chaque modèle (H_n) étant associée à une sous-séquence de trames acoustiques formant un sous-segment acoustique, pour délivrer une séquence (\widetilde{Q}_t) de valeurs de processus non observables associant une valeur à chaque trame acoustique, dite séquence alignée (\widetilde{Q}_t); et
- une étape (80) de détermination d'un indice de confiance (I_n) d'alignement acoustique pour chaque association entre un modèle (H_n) de la séquence et un segment acoustique (O(H_n)), dit indice (I_n) de confiance d'alignement de modèle et correspondant à une estimation de la probabilité a posteriori du modèle (H_n) étant donné l'observation du segment acoustique correspondant (O(H_n)), dite probabilité de modèle a posteriori (P_{mp}),

10

15

20

25

30

caractérisé en ce que chaque étape (80) de détermination d'un indice de confiance d'alignement (I_n) pour un modèle (H_n) comprend le calcul de la valeur dudit indice (I_n) au moins à partir d'une combinaison :

- de la probabilité d'observation de chaque trame acoustique étant donnée la valeur du processus non observable (Q), dite probabilité de modèle (P_m) et déterminée à partir de paramètres caractéristiques connus du modèle probabiliste (H_n) ;
- de probabilités de réalisation a priori de tous les modèles dudit répertoire indépendamment les uns des autres, dites probabilités de modèle a priori $(P(\lambda_i))$; et
- de l'estimation analytique $\left(\overline{d}(q^i_j)\right)$ de la durée moyenne d'occupation des valeurs du processus non observable du modèle.
- 2. Procédé selon la revendication 1, caractérisé en ce que chaque étape (80) de détermination d'un indice de confiance acoustique (I_n) pour un modèle comporte une sous-étape de détermination de l'estimation de la probabilité a priori de chaque valeur du processus non observable (Q) du modèle (H_n), dite probabilité de valeur a priori (P_{vp}), réalisée à partir de ladite estimation analytique $\left(\overline{d}(q_j^i)\right)$ de la durée moyenne d'occupation des valeurs du processus non observable du modèle.
- 3. Procédé selon l'une quelconque des revendications 1 ou 2, caractérisé en ce que chaque étape (80) de détermination d'un indice de confiance d'alignement (I_n) pour un modèle (H_n) comporte une sous-étape de détermination d'un indice de confiance pour chaque trame acoustique formant le segment acoustique associé audit modèle (H_n) et une sous-étape (88) de combinaison des indices de confiance de chaque trame dudit segment $(O(H_n))$ afin de délivrer ledit indice de confiance (I_n) dudit modèle (H_n) .
- 4. Procédé selon la revendication 3, caractérisé en ce que chaque sous-étape de détermination d'un indice de confiance pour une trame donnée comporte :
- une sous-étape (82) de calcul initial combinant la probabilité de modèle (P_m), la probabilité de modèle a priori du modèle en cours ($P(H_n)$) et la durée movenne d'occupation des valeurs non observables pour toutes les

10

15

20

25

valeurs du processus non observable de ladite séquence alignée $(\widetilde{\mathcal{Q}}_t)$ et du modèle en cours (H_n) ;

- une sous-étape (84) de calcul du produit de la probabilité de modèle (P_m) , de la probabilité de modèle a priori et de la probabilité de valeur a priori (P_{vp}) , réalisée pour chaque valeur du processus non observable (Q) de tous les modèles possibles (λ_1 à λ_I) dudit répertoire fini de modèles ; et
- une sous-étape (86) de sommation de tous lesdits produits pour tous les modèles (λ_1 à λ_I) possibles dudit répertoire fini de modèles, afin de délivrer ledit indice de confiance de ladite trame acoustique donnée à partir des résultats desdites sous-étapes (82, 84, 86).
- 5. Procédé selon l'une quelconque des revendications 1 à 4, caractérisé en ce que il comporte une sous-étape (90) de normalisation des indices de confiance par modèle (In) en fonction de la durée des modèles.
- 6. Procédé selon l'une quelconque des revendications 1 à 5, caractérisé en ce que ladite étape (20) automatique de détermination d'une séquence de modèles probabilistes correspondant à un texte donné (TXT) comporte :
- une sous-étape (22) d'acquisition d'une représentation graphémique dudit texte donné (TXT) ;
- une sous-étape (24) de détermination de ladite séquence (U) d'unités symboliques à partir de ladite représentation graphémique ; et
- une sous-étape (26) automatique de modélisation de ladite séquence (U) d'unités symboliques par sa décomposition sur une base desdits modèles probabilistes (λ_1 à λ_I) afin de délivrer ladite séquence (H_1^N) de modèles probabilistes.
- 7. Procédé selon la revendication 6, caractérisé en ce que ladite sousétape (24) de modélisation associe un unique modèle probabiliste (H_n) à chaque unité symbolique de ladite séquence (U) d'unités symboliques.
- 8. Procédé selon l'une quelconque des revendications 1 à 7, caractérisé en ce que ladite étape (40) de détermination d'une séquence de trames numériques (O_1^T) comporte :

10

15

20

25

- une sous-étape (42) d'acquisition d'un signal de parole (s(t)) correspondant à l'élocution dudit texte donné (TXT), adaptée pour délivrer une séguence d'échantillons numériques dudit signal de parole (s(t)); et
- une sous-étape (44) d'analyse spectrale desdits échantillons pour délivrer une décomposition du spectre fréquentiel dudit signal de parole (s(t)) sur une échelle non linéaire, ladite décomposition formant ladite séquence (O_1^T) de trames acoustiques.
- 9. Procédé selon la revendication 8, caractérisé en ce que ladite sousétape (44) d'analyse spectrale correspond à une sous-étape de transformation de Fourier dudit signal de parole (s(t)), de détermination de la distribution de son énergie sur une échelle non linéaire par filtrage, et de transformation en cosinus.
- 10. Procédé selon l'une quelconque des revendications 1 à 9, caractérisé en ce que ladite étape (60) d'alignement entre ladite séquence (O_l^T) de trames acoustiques et ladite séquence (H_l^N) de modèles comporte :
- une sous-étape (62) de calcul d'une pluralité d'alignements possibles chacun associé à un indice de pertinence ; et
- une sous-étape (64) de sélection d'un unique alignement parmi ladite pluralité d'alignements possibles.
- 11. Procédé selon la revendication 10, caractérisé en ce que ladite sous-étape (62) de détermination d'une pluralité d'alignements possibles comprend le calcul d'au moins un alignement optimal, tel que déterminé par un algorithme dit de Viterbi.
- 12. Procédé selon l'une quelconque des revendications 1 à 11, caractérisé en ce qu'il comporte en outre une étape (100) de modification locale de ladite séquence de modèles, en fonction desdits indices de confiance d'alignement (I_n) déterminés pour chaque modèle (H_n) de ladite séquence de modèles (H_n).
- 13. Procédé selon la revendication 12, caractérisé en ce que ladite étape (100) de modification locale comprend une sous-étape de suppression d'un modèle de ladite séquence de modèles.

10

15

20

25

- 14. Procédé selon la revendication 12, caractérisé en ce que ladite étape (100) de modification locale comporte une sous-étape de substitution d'un modèle de ladite séquence (H_1^N) de modèles par un autre modèle.
- 15. Procédé selon la revendication 12, caractérisé en ce que ladite étape (100) de modification locale comporte une sous-étape d'insertion d'un modèle entre deux modèles de ladite séquence (H_1^N) de modèles.
- 16. Procédé selon l'une quelconque des revendications 12 à 15, caractérisé en ce que lesdites étapes (60) d'alignement et de (80) calcul d'un indice de confiance sont répétées après chaque étape (100) de modification locale de ladite séquence de modèles.
- 17. Procédé selon l'une quelconque des revendications 1 à 16, caractérisé en ce que ladite étape (20) de détermination d'au moins une séquence de modèles est adaptée pour la détermination d'une séquence de modèles (H_1^N) correspondant à un texte donné et en ce que ladite séquence de trames acoustiques (O_1^T) est représentative de propriétés d'un signal de parole (s(t)) correspondant à la locution dudit même texte donné (TXT).
- 18. Procédé selon l'une quelconque des revendications 1 à 16, caractérisé en ce que ladite étape (20) de détermination de séquences de modèles est adaptée pour la détermination d'une pluralité de séquences de modèles correspondant chacun à un texte donné et en ce que ladite séquence de trames acoustiques est représentative de propriétés d'un signal de parole correspondant à la locution d'un texte quelconque, ledit procédé comportant une étape de sélection d'une ou plusieurs séquences de modèles parmi ladite pluralité, pour la réalisation de ladite étape de détermination d'indices de confiance.
- 19. Procédé selon l'une quelconque des revendications 1 à 18, caractérisé en ce que les dits modèles (H_n) sont des modèles dont les processus observables sont à valeurs discrètes, les valeurs des processus non observables étant les états (Q_t) de ces processus.
- 20. Procédé selon l'une quelconque des revendications 1 à 18, caractérisé en ce que lesdits modèles (H_n) sont des modèles dont les processus non observables sont à valeurs continues.




FIG.1

